

MATRICES EVOLUTIVAS

Fernando Galindo Soria

Escuela Superior de Cómputo (ESCOM)

Instituto Politécnico Nacional (IPN)

Av. Miguel Othón de Mendizábal y Av. Juan de Dios Bátiz s/n

Zacatenco, Cd. de México

07738 MÉXICO

fgalindo@ipn.mx

Original 27 de Septiembre de 1993

Ultimas modificaciones 31 de Mayo de 1998, 20 de Febrero de 1999

RESUMEN

En este trabajo se presentan las matrices evolutivas y se muestra como tres de las grandes áreas de la I.A.: Reconocimiento de Imágenes y en general de Formas, Sistemas Expertos y Redes Neuronales se pueden apoyar en su representación mediante Matrices Evolutivas.

Como primer punto se comenta que las matrices evolutivas surgieron de la conjunción de trabajos sobre redes neurales desarrollados en los años 70's y sistemas evolutivos para reconocimiento de imágenes realizados durante los 80's, como siguiente punto se presenta el uso de las matrices evolutivas en el tratamiento de imágenes y en el área de los sistemas expertos.

Finalmente se ve que, *las matrices evolutivas representan espacios n -dimensionales que permanentemente están cambiando. Originalmente la matriz evolutiva está vacía, por lo que el espacio que representa también lo está, mas adelante cuando llegan las primeras reglas o imágenes surgen los primeros puntos, pero estos no están fijos, ya que, cuando una regla de la matriz evolutiva se modifica el punto que la representa también cambia de posición, con lo que, en forma natural el espacio se está afinando y evolucionando.*

PALABRAS CLAVES:

Sistemas Evolutivos, Matrices Evolutivas, Redes Neuronales, Reconocimiento de Formas, Sistemas Expertos, Aprendizaje de Maquinas.

1.-) ANTECEDENTE: UNA REPRESENTACIÓN MATRICIAL PARA REDES NEURONALES.

A mediados de los 70's en un seminario de Inteligencia Artificial organizado en el Centro Nacional de Cálculo (CENAC) del IPN de la Cd. de México en colaboración con la Escuela Superior de Física y Matemáticas (ESFM) del mismo instituto, trabajando junto con Gustavo Nuñez Esquer llegamos a una representación de red neuronal[4].

Donde, a partir del modelo de neurona desarrollado por Mc Culott y Pitts[1][2][3], generamos nuestra propia propuesta, basada en una representación matricial de la red neuronal, en la cual cada una de las señales de entrada a las neuronas se representa como una columna de la matriz y cada una de las neuronas equivale a un renglón, de tal forma que, en la intersección de cada renglón y columna se almacena el valor que toma la dendrita en caso de que reciba una señal de entrada, como se puede ver en el siguiente ejemplo, donde la red neuronal de la figura 1:




Fig. 1 Ejemplo de una red neuronal.

Se representa como:

$$\begin{array}{cccccccc|c}
 a_1 & a_2 & a_3 & a_4 & a_5 & a_6 & a_7 & a_8 & h \\
 \hline
 -1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & h_1 \\
 0 & 0 & 0 & -1 & -1 & 1 & 0 & 0 & h_2 \\
 0 & 0 & 0 & 0 & 0 & 0 & 1 & -1 & h_3
 \end{array}
 \begin{array}{c}
 s_1 \\
 s_2 \\
 s_3 \\
 s_4 \\
 s_5 \\
 s_6 \\
 s_7 \\
 s_8 \\
 -1
 \end{array}
 =
 \begin{array}{c}
 n_1 \\
 n_2 \\
 n_3
 \end{array}$$

donde

$$\begin{array}{ll}
 \text{sí } n_1 \geq 0 \text{ entonces} & s_7=1 \\
 \text{sí } n_2 \geq 0 \text{ entonces} & s_8=1 \\
 \text{sí } n_3 \geq 0 \text{ entonces} & s_9=1
 \end{array}$$

La matriz representa a la red neuronal, el vector a las señales de entrada / salida a la red (s_j), los renglones representa a las neuronas (n_j) y las columnas corresponden a la señales de entrada a la neurona (a_k).

La matriz se multiplica por el vector de señales de entrada al sistema y si el valor resultante es mayor o igual a cero entonces se considera que la neurona es excitada por lo que se genera un valor de salida de la neurona igual a uno.

2.-) MATRIZ EVOLUTIVA Y RECONOCIMIENTO DE FORMAS.

El anterior es un modelo simple de red neuronal representada mediante una matriz y actualmente es común encontrar representaciones matriciales de redes neuronales, por lo que el modelo desarrollado en 1976 se podría ver como antecedente y como un resultado independiente.

Sin embargo desde el principio se presentó el problema de obtener los valores de las neuronas y es ahí donde a mediados de los 80's, Cuitláhuac Cantú [4][5], al estar trabajando sobre reconocimiento de imágenes llegó en forma independiente a una representación matricial prácticamente equivalente a la encontrada para las redes neuronales, pero con capacidades evolutivas[6][7][8].

En esta idea se parte de que originalmente la matriz está vacía y lo que hace el sistema es llegar y buscar una imagen, como no encuentra nada la coloca en el primer renglón, mas adelante cuando llega la segunda imagen, si son similares la reconoce y la acumula con la primera si no son similares entonces la coloca en el siguiente renglón y así sucesivamente.

Para lo cual cada imagen se representa como un vector, de tal forma que por ejemplo, si se tiene un gato, un perro y un ratón, cada uno de ellos

se almacena como un vector y entre los tres forman una matriz como la siguiente

a ₁	a ₂	a ₃	a ₄	a ₅	a ₆	a ₇	a ₈	a ₉	
1	0	1	0	0	1	0	1	0	gato
0	1	0	1	0	1	1	0	1	perro
1	1	0	0	1	0	0	1	1	ratón

Si se perciben varios gatos, en lugar de almacenar cada gato en un vector independiente se suman los vectores que representan cada uno de los gatos y el resultado se toma como la representación de la estructura general del gato y se almacena en la matriz.

(5 1 4 0 0 5 0 4 1 20) gato

Por otro lado si se tienen varios gatos, perros y ratones, la matriz sería de la forma:

a ₁	a ₂	a ₃	a ₄	a ₅	a ₆	a ₇	a ₈	a ₉	h	
5	1	4	0	0	5	0	4	1	20	gato
0	3	0	3	0	2	3	2	1	14	perro
1	1	0	0	1	0	0	1	1	5	ratón

Donde cada renglón representa un tipo de objeto y *h* es un valor donde se acumula el número de puntos en el vector (En este caso se puso *h* como la suma de los valores del vector por facilidad del ejemplo, sin embargo existen otros métodos para asignar este valor).

Lo anterior es equivalente a que cada gato se dibujara en un acetato y posteriormente se superpusieran los acetatos, con lo que las características repetitivas del gato quedan más recalcadas y equivale a números mayores en el vector que lo representa.

Si se desea reconocer un nuevo objeto, se representa también como un vector, se multiplica por la matriz, se ve en que renglón se obtuvo el máximo valor y se le asocia a ese renglón el objeto. Por ejemplo si tomamos la matriz anterior y llega el objeto 1 0 1 0 0 1 0 1 0, se multiplica por la matriz y les restamos el valor de *h* quedando: -2 para el gato, -10 para el perro y -3 para el ratón. De donde se propone que el objeto reconocido es un gato.

Como siguiente punto el sistema acumula el nuevo vector en la matriz, con lo que, en el ejemplo anterior el nuevo vector se suma al renglón del gato y la matriz queda:

a ₁	a ₂	a ₃	a ₄	a ₅	a ₆	a ₇	a ₈	a ₉	h	
6	1	5	0	0	6	0	5	1	24	gato
0	3	0	3	0	2	3	2	1	14	perro
1	1	0	0	1	0	0	1	1	5	ratón

Con lo que, el sistema evolutivo esta transformando permanentemente su imagen de la realidad.

Como se puede observar este método reúne la característica de que esta evolucionando en forma natural y encontrando la imagen acumulada (y por tal, la imagen promedio), *con lo que no existe un proceso previo de aprendizaje y otro de aplicación, sino que por el proceso natural de conocer y reconocer las imágenes va evolucionando.*

Es importante observar que, la matriz obtenida es prácticamente igual a la de la red neuronal de 1976, con lo que se plantea como un mecanismo para la representación de sistemas evolutivos y en particular de *redes neuronales evolutivas, ya que, los valores de la matriz están cambiando en tiempo real y ésto es equivalente a modificar las interrelaciones entre las neuronas* (ya que en el modelo original cada entrada de la matriz representa una conexión entre neuronas y estas conexiones se están modificando en tiempo real). Lo anterior es la base de un proyecto desarrollado por Alejandrina Salazar Torres sobre redes neuronales evolutivas en 1993.

Este mecanismo de matriz que se esta transformando permanentemente se conoce como *matriz evolutiva* [4] y tiene la ventaja de que siempre se está actualizando para reflejar una imagen de la realidad. Las matrices evolutivas constituyen por si solas una herramienta con múltiples aplicaciones [9][10][11][12][13].

3.-) MATRIZ EVOLUTIVA Y SISTEMAS EXPERTOS.

Otro campo donde se pueden aplicar las matrices evolutivas es en el área de los sistemas expertos, por ejemplo, si partimos de un sistema experto de diagnostico[14] formado por reglas de la forma

$$S_1 S_2 S_3 \dots S_n \Rightarrow D_i : T_j$$

donde S_j son los síntomas, D_i los diagnósticos y T_i los tratamientos (o sea que un conjunto de síntomas generan un diagnóstico y un tratamiento).

El sistema experto puede representarse como una matriz, donde cada columna corresponde a un síntoma y cada renglón a una regla del experto.

$$\begin{array}{c|cccc} & S_1 & S_2 & S_3 & \dots & S_n \\ r_1 & 1 & 0 & 0 & \dots & 0 \\ r_2 & 0 & 1 & 1 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ r_m & 1 & 0 & 1 & \dots & 1 \end{array}$$

De tal manera que si aparece un 1 en el renglón i y la columna j , quiere decir que la regla i necesita el síntoma j para cumplirse.

Aquí es importante comentar que, una de las características que permite la representación de las reglas de inferencia mediante una matriz es que no importa el orden en el que se presenten los síntomas, o sea que, la cadena lingüística es conmutativa bajo la concatenación lo cual no ocurre por ejemplo con las oraciones del Español las cuales no se pueden representar en general mediante la matriz, porque no se permite la conmutabilidad.

Ahora bien los valores de la matriz pueden ser cualesquiera, por lo que a cada síntoma se le puede dar un valor diferente dependiendo del grado de importancia, o de la probabilidad o de la frecuencia de ese síntoma en particular, con lo que se tiene una matriz borrosa de la forma:

$$\begin{array}{c|cccc} & S_1 & S_2 & S_3 & \dots & S_n \\ r_1 & a_{11} & a_{12} & a_{13} & \dots & a_{1n} \\ r_2 & a_{21} & a_{22} & a_{23} & \dots & a_{2n} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ r_m & a_{m1} & a_{m2} & a_{m3} & \dots & a_{mn} \end{array}$$

donde a_{ij} es el peso que tiene el síntoma j en la regla i . Entonces si llega un problema que tiene por ejemplo los síntomas 1, 3, 7,..., n , con pesos 0.5, 1.3, 0.7,..., 2.5, solo se requiere representar el problema como el vector: (0.5 0 1.3 0 0 0 0.7 2.5) y operar el vector con la matriz.

La forma más fácil de operar el vector con la matriz consiste en tomar el vector y multiplicarlo por la matriz con lo que se tiene un vector resultante y solo se requiere buscar el elemento i

máximo para detectar a que regla corresponde el conjunto de síntomas.

Por ejemplo, si se tiene la siguiente matriz:

$$\begin{array}{c|cccccc} & S_1 & S_2 & S_3 & S_4 & S_5 & S_6 \\ r_1 & 3.2 & 0 & 4.0 & 6.5 & 0 & 0 \\ r_2 & 2.0 & 1.3 & 0 & 0 & 1.5 & 0 \\ r_3 & 0 & 3.0 & 0 & 0 & 4.2 & 2.0 \end{array}$$

y llega un problema con los síntomas (1.0 0 1.5 0 0 0.7), entonces se multiplica la matriz por el vector quedando el resultado:

$$\begin{array}{c|c} r_1 & 9.2 \\ r_2 & 2.0 \\ r_3 & 1.4 \end{array}$$

de donde se propone la r_1 como el resultado del sistema.

Una de las ventajas de representar al sistema experto mediante una matriz es que ahora se puede ver y atacar con múltiples herramientas incluyendo entre otras la lógica difusa, redes neurales, teoría de la medida y sistemas evolutivos. En particular podemos aplicar las técnicas de matrices evolutivas y partir de que la matriz está originalmente vacía y llena de ceros, cuando llegan los primeros síntomas y no encuentra nada almacena el vector en el primer renglón y asigna el diagnóstico (le puede pedir el diagnóstico al experto humano).

Por ejemplo, si llegan los síntomas (1.2 0 0 2.3 0 0.7) el sistema busca en la matriz el diagnóstico, pero como esta vacía no los encuentra, entonces pregunta por el diagnóstico y genera una matriz con un renglón.

$$\begin{array}{c|cccccc|c} & S_1 & S_2 & S_3 & S_4 & S_5 & S_6 & \\ r_1 & 1.2 & 0 & 0 & 2.3 & 0 & 0.7 & D_1 \end{array}$$

Si llegan ahora los síntomas (0.7 0 0 0 3.2 0), como la colisión con el vector almacenado es baja, pregunta por el diagnóstico, si el nuevo diagnóstico es diferente crea un nuevo renglón, quedando la matriz:

$$\begin{array}{c|cccccc|c} & S_1 & S_2 & S_3 & S_4 & S_5 & S_6 & \\ r_1 & 1.2 & 0 & 0 & 2.3 & 0 & 0.7 & D_1 \\ r_2 & 0.7 & 0 & 0 & 0 & 3.2 & 0 & D_2 \end{array}$$

Si llega una cadena de síntomas con alta colisión, como por ejemplo:

$$(1.0 \ 0 \ 0 \ 0.8 \ 0 \ 1.2)$$

el sistema emite el diagnostico D_1 y acumula el nuevo síntoma sobre la matriz anterior en el renglón 1:

	S_1	S_2	S_3	S_4	S_5	S_6		# de acumu lados
r_1	2.2	0	0	3.1	0	1.9	D_1	2
r_2	0.7	0	0	0	3.2	0	D_2	1

Al tener el vector acumulado se están reforzando los síntomas y en forma natural aumentan los pesos.

El sistema siempre suma. Si llega una cadena de síntomas con alta colisión los suma al renglón diagnosticado. Si llega una nueva cadena crea un nuevo renglón. Si llega una cadena y el experto indica que corresponde a un diagnostico presente, la nueva cadena se acumula a este diagnostico.

Si se toma el vector acumulado y cada síntoma lo dividimos entre el número de acumulados tenemos una regla promedio, por lo que, lo que estamos encontrando es la regla promedio asociada a un diagnostico y mediante el mecanismo evolutivo esta regla se está depurando y afinando cotidianamente, o sea que, en forma natural y permanente se están encontrando y afinando las reglas del sistema.

4.-) UNA REPRESENTACIÓN N-DIMENSIONAL.

Si analizamos un poco mas a las matrices evolutivas vemos que cada imagen, regla o cadena de síntomas promedio se representa mediante un conjunto de n síntomas o variables, si estas variables son independientes entre si entonces cada objeto (imagen, regla o cadena de síntomas promedio) representado por las n variables se puede visualizar como un punto en un espacio de n dimensiones.

O sea que cada vector de la matriz evolutiva representa un punto en un espacio multidimensional y todas las reglas forman una nube de puntos. De donde, por ejemplo, el proceso de encontrar el diagnostico asociado a un vector de síntomas equivale a encontrar el punto que tiene distancia mínima con este vector.

Ahora bien, conforme aumenta la cantidad de variables que representan a los objetos la posibilidad de que colisionen (asocien el mismo punto a objetos diferentes) disminuye.

Para mostrar lo anterior supondremos que se tienen varios objetos y cada objeto se representa con un valor de una variable o como un punto en una dimensión, en su momento varios objetos podrían tomar el mismo valor y caer en el mismo lugar.

Por ejemplo, si se quiere representar a los alumnos de un grupo por sus calificaciones y éstas toman puros valores enteros y tienen una distribución uniforme entre 0 y 10 entonces la calificación puede tomar 11 posibles valores.

Si $[[a, b]]$ es el número de valores posibles entonces la distancia entre a y b se denota como μ y nos indica el rango de valores, o sea que $\mu = (b - a) + 1$. En el ejemplo anterior $\mu = (10 - 0) + 1 = 11$.

A la relación entre el número de valores posibles $[[0, 10]]$ y el número de objetos (alumnos), se le conoce como densidad o ρ y en general se define como $\rho = \lambda / \mu$ (donde el número de objetos se denota por λ).

La densidad entre otras cosas indica que tan factible es que dos objetos colisionen o sea que tomen el mismo valor. Por ejemplo si $\mu = 11$ y se tiene 1 persona entonces $\rho = 1 / 11$, pero si se tienen 2 personas $\rho = 2 / 11$. Si se tienen 10 personas entonces $\rho = 10 / 11$ y es muy posible que dos personas tomen el mismo valor, en fin, si se tienen 20 personas, es seguro que varias personas tomen el mismo valor.

Por lo que si se quiere distinguir entre varios objetos midiendo una variable con distribución uniforme se necesita que ρ sea menor que uno, o sea que el número de objetos sea menor que el número de valores posibles que toma la variable.

Para el ejemplo de las personas la calificación no es una buena variable ya que en general en un grupo se tienen mas de 10 alumnos y además la distribución no es uniforme. Otra variable mejor podría ser la altura en centímetros (nuevamente supondremos el caso ideal de distribución uniforme y que la probabilidad de tomar cualquier valor es la misma)

Si el rango de altura es [151, 170] cm. entonces $\mu = (170 - 151) + 1 = 20$, si se tienen pocos alumnos funciona pero al final tampoco es un buen criterio para discriminar entre alumnos.

Ahora bien, si se tienen dos variables no correlacionadas y se utilizan combinadas el espacio se multiplica, o sea que si se categoriza a un conjunto de objetos mediante 2 variables independientes y si μ_1 es el número de puntos en x , y μ_2 es el número de puntos en y entonces $\mu_1 * \mu_2$ es el número de puntos en el espacio de valores (conocido también como espacio de caos).

Por ejemplo, en el caso de los alumnos, si μ .calificación = 11 y μ .tamaño = 20 entonces μ .espacio = μ .calificación * μ .tamaño = $11 * 20 = 220$. Con lo que el espacio crece y las colisiones se reducen.

Si se tienen 3 o 4 o más variables rápidamente se llega a espacios con una gran cantidad de posibles valores, por lo que si se tienen objetos caracterizados por 1000 variables la posibilidad de que 2 objetos diferentes tomen el mismo valor es muy pequeña.

Si dejamos de suponer una distribución uniforme y suponemos una distribución normal, se tiene que el comportamiento del espacio probabilístico para una variable es de forma normal.

Si tenemos dos variables x , y se tiene un espacio donde se interceptan dos curvas normales. El espacio con centro en (x .media, y .media) y que tiene como radios la varianza de x y la varianza de y se conoce como elipse de Chebichev.

Conforme aumenta la cantidad de variables se termina teniendo una hiperelipse de Chebichev de n dimensiones con la característica de que todos los puntos de la hiperelipse se pueden ver como casos particulares de un mismo objeto representado por el punto medio ($d_1, d_2, d_3, \dots, d_n$) de la elipse. O sea que todos los puntos "cercaños" a ($d_1, d_2, d_3, \dots, d_n$) se pueden considerar como ejemplos del mismo objeto o como objetos similares.

De donde una técnica para reconocer un objeto o fenómeno o patrón de algún tipo consiste en encontrar su representación "promedio" en un espacio de n dimensiones y todos los objetos cercanos (que caen dentro de la elipse de

Chebichev) se pueden considerar como objetos similares.

5.-) ESPACIOS N-DIMENSIONALES EVOLUTIVOS

Este enfoque se ha aplicado desde hace muchos años por ejemplo para el reconocimiento de imágenes y señales, ya que al digitalizar una señal o curva cada valor digitalizado corresponde a una variable, por lo que, por ejemplo una imagen de 600×500 pixels o sea que esta formada por 300000 puntos, corresponde a un punto representado por 300000 (trescientos mil) variables o sea que *cada imagen corresponde a un punto en un espacio de 300000 dimensiones*. Con lo que la posibilidad de que dos objetos no similares colisionen es pequeña.

Otra aplicación de esta idea se presenta en el área de los sistemas expertos, donde en general si se tienen n síntomas o variables e_1, e_2, \dots, e_n , donde $e_i \in [a_i, b_i]$. y las variables son independientes o están muy poco correlacionadas entre sí, entonces la regla $e_1 e_2 \dots e_n$ se puede ver como un punto en un espacio n -dimensional y el número de valores diferentes que puede tomar es $\prod ((b_i - a_i) + 1)$.

Para darnos cuenta de lo que esto significa supongamos que se tienen 12 síntomas e_1, e_2, \dots, e_{12} y cada síntoma puede tomar 10 posibles valores, entonces se tienen $10 * 10 * 10 \dots * 10 = 10^{12}$ combinaciones y la probabilidad de que dos objetos diferentes tomen los mismos valores es de $1/10^{12}$.

Como se puede ver conforme aumenta el número de variables o síntomas la posibilidad de que los objetos colisionen disminuye. Lo anterior es la base de una técnica de reconocimiento de formas conocida como análisis de cúmulos, que básicamente toma una muestra significativa de objetos similares, los representa como puntos en un espacio n -dimensional, encuentra la media y la varianza de estos puntos y cuando llega un objeto nuevo al sistema, mide la distancia entre el punto nuevo y el punto medio, si esta es pequeña lo reconoce como un objeto similar y si no lo desecha.

Sin embargo es común que cuando se aplica esta técnica, los patrones o espacios de Chebichev ya están prefijados, ya sea porque explícitamente fueron asignados o porque se

obtuvieron mediante un proceso de aprendizaje y quedaron fijos e inmutables. Ahora bien, en el caso de las matrices evolutivas también cada imagen, regla o cadena de síntomas promedio se representa como un punto en un espacio de n dimensiones, o sea que, todas las reglas forman una nube de puntos, pero con la característica de que *la matriz evolutiva permanentemente se esta modificando*.

Originalmente la matriz evolutiva esta vacía y representa un espacio que también lo esta, más adelante cuando llegan las primeras reglas o imágenes surgen los primeros puntos, pero estos no están fijos, ya que, cuando una regla de la matriz evolutiva se modifica el punto que la representa también cambia de posición, o sea que, en forma natural y permanente el espacio n -dimensional se esta afinando y evolucionando.

CONCLUSIÓN

En este trabajo se mostró como tres de las grandes áreas de la I.A.: Reconocimiento de Imágenes y en general de formas, Sistemas Expertos y Redes Neuronales se pueden apoyar en la representación mediante Matrices Evolutivas, que originalmente se encuentran vacías y se van llenando y afinando conforme fluyen los datos.

En las matrices evolutivas cada imagen, regla o cadena de síntomas promedio se representa como un punto en un espacio de n dimensiones, o sea que, todas las reglas forman una nube de puntos en un espacio n -dimensional. De donde por ejemplo, el proceso de encontrar el diagnostico asociado a un vector de síntomas equivale a encontrar el punto que tiene distancia mínima con este vector.

La idea de considerar algo como un punto n -dimensional no es nueva y se ha atacado dentro del reconocimiento de formas mediante el Análisis de Cúmulos y la Taxonomía Numérica. En particular si se representan todos los puntos que corresponde a un diagnostico específico éstos forman una nube, donde el vector promedio corresponde al centro de gravedad de la nube.

Ahora bien una de las características de *la matriz evolutiva*, es que *permanentemente se está modificando, originalmente la matriz evolutiva esta vacía y representa un espacio que*

también lo está, más adelante cuando llegan las primeras reglas o imágenes surgen los primeros puntos, pero estos no están fijos, ya que, cuando una regla de la matriz evolutiva se modifica el punto que la representa también cambia de posición, o sea que, en forma natural y cotidiana el espacio n -dimensional se está afinando y evolucionando.

Con lo que el sistema evolutivo está transformando permanentemente su imagen de la realidad y no existe un proceso previo de aprendizaje y otro de aplicación, sino que por el proceso natural de fluir las imágenes o reglas va evolucionando.

FUENTES DE INFORMACIÓN.

[1] Minsky, Marvin y Papert, Seymour, "Perceptrons, An Introduction to Computational Geometry"

[2] Minsky, Marvin, "Finite and Infinite Machines"

[3] Kleene, S. C., "Representation of Events in Nerve Nets and Finite Automata", Automata Studies

[4] Galindo Soria, Fernando, "Una Representación Matricial para Sistemas Evolutivos", Conferencia Magistral Symposium Internacional de Computación, IPN-CENAC, México, 1993

[5] Cantú Rohlík, Cuitláhuac, comunicaciones personales y cursos de Representación del Conocimiento, Inteligencia Artificial y Redes Neuronales

[6] Galindo Soria, Fernando, "Sistemas Evolutivos", en Boletín de Política Informática, INEGI-SPP, México. Sept 1986.

[7] Galindo Soria, Fernando, "Sistemas Evolutivos: Nuevo Paradigma de la Informática" Memorias de la XVII Conferencia Latinoamericana de Informática, Caracas, Venezuela, Julio, 1991

[8] Galindo Soria, Fernando, "Arquitectura Lingüístico-Interactiva para Sistemas Evolutivos" en "La Inteligencia Artificial en México", Ed. Universidad Tecnológica de la Mixteca (UTM) 1993

[9] Torres Hernández, Luis E, Longoria, Luis C., Rojas Salinas, Antonio, "Aplicación de los Sistemas Evolutivos en el Análisis de Espectros de Rayos Gamma", en Memorias del Cie/95, Primera Conferencia de Ingeniería Eléctrica CIE/95, CINVESTAV-IPN, Septiembre 11-13 de 1995 México, D.F.

[10] De La Cruz Sánchez, Eduardo, Longoria Gándara, Luis C., Carrillo Mendoza, Rodolfo A., *"Sistema Evolutivo para el Diagnóstico de Fallas en Maquinas Rotatorias"*, en Memorias del Cie/95, Primera Conferencia de Ingeniería Eléctrica CIE/95, CINVESTAV-IPN, Septiembre 11-13 de 1995 México, D.F.

[11] Arzola Carvajal, Irene, Cruz Reyes, José Rafael, *"Sistema Evolutivo para el Reconocimiento de Texto Taquigrafico"*, en Memorias del Cie/95, Primera Conferencia de Ingeniería Eléctrica CIE/95, CINVESTAV-IPN, Septiembre 11-13 de 1995 México, D.F.

[12] García García, Diana Karla, Salcido Bustamante, Sergio, Ventura Silva, Alfonso, *"Sistema Evolutivo de Reconocimiento de Formas en dos Dimensiones"*, en Concurso Nacional de Ciencia y Tecnología, CONADE, México, 1996

[13] Olivares Ceja, Jesús Manuel, *"Sistema Evolutivo Reconocedor de Textos"*, IPN-CIC, México, febrero, 1997 en "Teoría y Práctica de los Sistemas Evolutivos" Versión Beta, México 1997

[14] Galindo Soria, Fernando, y Ortiz Hernández, Javier, *"Sistema Evolutivo Constructor de Sistemas Expertos"*, CENIDET-DGIT, UPIICSA-IPN, Noviembre, 1988, en "Teoría y Práctica de los Sistemas Evolutivos" Versión Beta, México 1997